联合边路和中路解码特征学习的多描述编码图像增强方法 *

赵利军 [1†]，曹聪颖 [1]，张晋京 [2]，白慧慧 [3]，赵　耀 [3]，王安红 [1]

(1. 太原科技大学 电子信息工程学院，太原 030024; 2. 中北大学 大数据学院，太原 030051; 3. 北京交通大学 信息科学研究所，北京 100044)

摘　要：提出一种联合边路和中路解码特征学习的多描述编码图像增强方法，该方法同时考虑了边路解码图像增强和中路解码图像增强的问题，因而可以通过联合学习优化中路解码和边路解码的特征来实现更好的网络训练。首先，考虑到多描述编码的边路独立解码和中路联合解码的特性，提出一种网络共享的边路低分辨率特征提取网络来有效地提取具有相同内容和差异细节的两个边路解码图像的特征，同时设计一种残差递归补偿网络结构并将其用于边路与中路低分辨率特征提取网络。其次，设计一个多描述边路上采样重建网络，该重建网络采用部分网络层参数共享策略，该策略能够减小网络模型参数量，同时提高网络的泛化能力。最后，提出一种多描述中路上采样重建网络，将两个边路低分辨率特征与中路低分辨率特征进行深层特征融合来实现多描述压缩图像的增强。大量的实验结果表明：在模型复杂度、客观质量和视觉质量评价方面，所提的方法优于很多的图像增强方法如 ARCNN、FastARCNN、DnCNN、WSR 和 DWCNN。

关键词：多描述编码；深度学习；图像增强；压缩失真；特征融合

中图分类号：TP391　　doi: 10.19734/j.issn.1001-3695.2022.02.0061

Multiple description coding image enhancement method with joint learning of side- and central-decoding features

Zhao Lijun[1†], Cao Congying[1], Zhang Jinjing[2], Bai Huihui[3], Zhao Yao[3], Wang Anhong[1]

(1. *College of Electronic Information Engineering*, *Taiyuan University of Science & Technology*, *Taiyuan* 030024, *China*; 2. *College of Big Science & Technology*, *North University of China*, *Taiyuan* 030051, *China*; 3. *Institute of Information Science*, *Beijing Jiaotong University*, *Beijing* 100044, *China*)

Abstract: This paper proposes MDC image enhancement method by using joint learning of side- and central-decoding features, which considers the problems of side decoding image enhancement and central decoding image enhancement at the same time, so it can realize better network training by optimizing central decoding and side decoding features through joint learning. First, considering side independent decoding and central joint decoding features for MDC, this paper proposed a network-sharing side low-resolution feature extraction network to effectively extract features from two-side decoded images with the same content and different details, while it design a residual recursive compensation network structure and apply it into both side and central low-resolution feature extraction network. Secondly, a multiple description up-sampling reconstruction network is designed, which adopts parameter sharing strategy for partial layers of network, which can reduce parameter number of network model and improve network generalization ability. Finally, multiple description central up-sampling reconstruction network is proposed to perform deep feature fusion with two low-resolution side features and central features to enhance multiple description compressed images. A large number of experimental results have shown that the proposed method is superior to several image enhancement methods such as ARCNN, FastARCNN, DnCNN, WSR and DWCNN in terms of model complexity, objective quality and visual quality assessment.

Key words: multiple description coding; deep learning; image enhancement; compression distortion; feature fusion

0　引言

虽然现有的通信系统能够提供很宽的网络带宽，但是在人群密集的演唱会现场、足球比赛场地和学生宿舍楼群等场所常常会发生网络拥堵现象。此外，在很多情况下有限的通信设备资源会导致不可靠信道的数据包以很大的概率发生丢失。虽然很多现有的高效图像压缩标准能够缓解该问题，但是无法保证数据的可靠传输。不同于单描述编码，多描述编码(Multiple Description coding, MDC)将一个信源分成多个描述，在不同的信道上传输不同描述的数据。如果在接收端能够完全正确地接收到所有描述的数据包，那么，通过联合解码就能恢复出高质量的图像。如果在接收端只接收到一个描述的数据包，那么，通过边路解码器能够恢复出一个较高质量的图像。由此可见，多描述编码技术能实现图像的可靠传输。

虽然多描述编码方法可以减少数据量，但是经过压缩的中路和边路图像会发生不同程度的失真，特别是接收到的边

收稿日期：2022-02-07；**修回日期：**2022-04-07　**基金项目：**太原科技大学博士科研启动基金资助项目(20192023)；山西省基础研究计划资助项目(202103021223284)；来晋工作优秀博士奖励资金资助项目(20192055)；太原科技大学研究生教育创新项目(XCX212029)；国家自然基金资助项目(61972023，62072325)

作者简介：赵利军(1989-)，男(通信作者)，山西太原人，讲师，硕导，博士，主要研究方向为多描述编码、图像压缩和图像增强等(leejun@tyust.edu.cn)；曹聪颖(1996-)，女，山西临汾人，硕士研究生，主要研究方向为图像增强和图像压缩；张晋京(1992-)，女，山西太原人，博士研究生，主要研究方向为图像压缩、图像增强和图像分割；白慧慧(1979-)，女，北京人，教授，博导，博士，主要研究方向为多描述编码、图像压缩和图像复原等；赵耀(1967-)，男，北京人，教授，博导，博士，主要研究方向为图像与视频处理、数字水印与数字取证、图像/视频检索与内容理解等；王安红(1972-)女，山西太原人，教授，博导，博士，主要研究方向为图像和视频编码、多描述编码等.

路图像存在严重失真，因此，非常有必要使用图像压缩伪影去除技术来提升 MDC 图像的解码质量。通常，将压缩伪影去除技术分成两类：传统的压缩伪影去除方法和基于深度学习的压缩伪影去除方法。例如，Dabov 等人[1]提出了一种基于变换域的增强稀疏表示策略，并且通过分组和协同滤波来实现图像去噪。Foi 等人[2]提出了基于形状自适应离散余弦变换的图像滤波方法，该方法定义了一种区域形状自适应的变换来有效地去除图像的块效应和边缘振荡效应。Chang 等人[3]通过稀疏表示和冗余字典学习来减少 JPEG(Joint Photographic Experts Group)压缩所带来的伪影，但是该方法无法恢复丢失的一些高频信息。Zhang 等人[4]提出了一种基于非凸低秩模型的图像去块方法，该方法的优势在于不改变现有编解码器的情况下，将量化约束显式地变换到可行解空间来约束非凸的低秩优化，同时该方法通过一种自适应参数调整的交替最小化策略来解决对应的优化问题。

在 ImageNet 图像识别大赛上 AlexNet 一举夺冠，标志着进入了现代深度学习的萌芽时期。随后，AlphaGo 以 4:1 的比分战胜了国际顶尖围棋高手李世石。自此，卷积神经网络(Convolutional Neural Networks, CNN)得到广泛的关注和发展。在计算机视觉领域深度学习取得巨大成功，同时它能够解决图像超分、去雨、去雾和去噪等任务。基于深度学习的压缩伪影去除的方法也受到研究者的广泛关注。例如，Yu 等人[5]提出了一种图像压缩伪影去除的方法并命名为 ARCNN(Artifacts Reduction Convolutional Neural Network)，该方法验证了重用浅层网络的参数有利于训练模型的深层网络。为了解决深层网络难训练的问题，Zhang 等人[6]提出了一种基于残差学习的神经网络去噪方法，并将其命名为 DnCNN(Denoising Convolutional Neural Network)，该方法利用残差学习和批归一化操作构建深层卷积神经网络，这种设计有助于提升网络的收敛速度和去噪性能。为了进一步提升图像增强的性能，Qiu 等人[7]提出了一种基于深度残差学习的 JPEG 压缩伪影去除方法，该方法将基于信号处理的图像恢复方法与深度残差学习模型相结合来恢复原始数据。虽然以上方法能够获得比传统的压缩伪影去除方法更好的性能，但是这些方法没有充分利用图像的上下文信息来实现图像质量的增强。为了解决这个问题，Chen 等人[8]提出了一种多尺度稠密残差网络，该网络将不同空洞因子的空洞卷积引入到残差网络的稠密模块，并构建一种多尺度稠密模块来获得更大的感受野。

不同于神经网络单域处理方法，Zhang 等人[9]提出了一种双域多尺度卷积神经网络方法(Dual-domain Multi-scale Convolutional Neural Network, DMCNN)，该网络能够有效地利用全局信息来消除 JPEG 压缩伪影。类似于 DMCNN 方法，Zheng 等人[10]提出了一种隐式双域卷积网络(Implicit Dual-domain Convolutional Network, IDCN)来减少彩色图像的压缩伪影。虽然 DMCNN 与 IDCN 都采用了双支路的网络拓扑结构，但它们并没有充分地利用图像的高低频信息来实现特征互补。为了充分地利用图像高低频特征，Jin 等人[11]提出了一种灵活的深度学习图像恢复方法，该方法首先将低质量的输入图分解为低频结构图和高频纹理图；其次，将两个图像分别送入质量增强网络，并将纹理特征用于增强结构特征；最后，使用聚合网络将预测的高质量纹理图和结构图合并起来。为了解决池化和膨胀滤波等带来的网格化问题，Liu 等人[12-13]提出了一种多级小波卷积神经网络(Multi-level Wavelet Convolutional Neural Network, MWCNN)，该网络在图像去噪、单幅图像超分辨率和 JPEG 图像伪影去除等方面具有良好的效果。为了解决图像增强性能、网络参数量和推理时间之间的权衡问题，Zhang 等人[14]提出一种轻量化的快速超分辨网络(Wavelet Super-Resolution, WSR)，该方法提出一种可变形卷积核来减少网络参数。

虽然以上的这些方法可以取得良好的去噪性能，但是这些方法无法针对不同级别的压缩伪影实现自适应的图像增强。这些方法往往需要训练多个去噪网络模型，这将必然提升图像增强方法的复杂度，而且经过训练的多个模型将占用较大的存储空间，因此这些方法很难被广泛地采用。为了解决这一问题，Li 等人[15]提出了一种面向不同质量因子 JPEG 压缩的单模型压缩伪影去除方法，该方法分别使用恢复支路和全局支路来解决局部震荡伪影、全局的块伪影和颜色漂移问题。此外，Kirmemis 等人[16]提出了一种 BPG(Better Portable Graphics)图像压缩的伪影去除方法，该算法需要从三个不同大小的压缩伪影去除网络中选择一个网络对图像进行去噪，但是如何挑选最佳的伪影去除网络是一个非常棘手的问题。除了压缩图像的增强问题外，很多的研究者致力于解决视频压缩质量增强问题。例如，Zhou 等人[17]提出一种基于双网络的压缩视频重建方法，该方法先用压缩网络去除压缩伪影，再使用超分辨率网络进一步提高视频质量。

为了解决多描述编码图像的压缩失真问题，Xuan 等人[18]通过相邻关键帧估计来实现压缩图像的增强。Zhao 等人[19]将图像预处理和后处理技术结合起来，构建了一种兼容标准编码器的多描述编码新框架，该框架极大地提升了图像的编码效率和解码图像质量。类似地，Zhang[20]等人通过棋盘格下采样的方法获得多个单描述图像，然后使用标准编码器进行编码，最后使用卷积神经网络来增强单路和中路解码图像质量。Purica[21]等人提出将视频序列的两个低分辨率压缩描述合并为一个高分辨率描述。Zhang[22]等人采用奇偶分离的采样方式对接收到的边路描述进行重构增强。Zhu[23]等人提出一种压缩约束去块算法，该算法有效地利用接收到的两个描述信息来减少中路解码图像的边界伪影。Xu[24]提出一种基于 3D-LVQ (3D Lattice Vector Quantization)的图像编码预测解码方法，该方法能够提高边路图像解码的性能。总而言之，这些深度学习模型往往很难满足轻量化设备的需求，因此，需要研究低复杂度的深度学习模型。为了解决多描述压缩图像出现的压缩伪影问题，特别是边路解码图像会出现严重的结构分裂伪影问题，本文提出一种联合边路和中路解码特征学习的多描述压缩图像增强方法(MDE)。本文贡献点总结如下：

a)为了解决现有深度学习模型占用存储空间大、计算复度高的问题，设计了一种残差递归补偿网络并将其作为边路和中路的低分辨率特征提取网络，而且使用参数共享策略来有效地提取两个具有内容相同而细节存在差异的两描述解码图像特征。

b)考虑到多描述编码的边路独立解码特性，设计了多描述边路上采样重建网络。多描述边路上采样重建网络也采用部分网络层参数共享策略，从而减小所提方法的网络模型参数量并提高网络的泛化能力。

c)考虑到多描述编码的中路联合解码的特性，设计了一种多描述中路上采样重建网络将两个边路低分辨率特征和中路低分辨率特征进行深层特征融合来实现多描述压缩图像的增强。

1　所提的多描述压缩图像增强方法

虽然现有的多描述编码方法能够有效地解决在不稳定网络环境下图像的可靠传输问题，但是有损的多描述编码难免会导致解码图像出现各种伪影、噪声、结构变形和结构分离等问题。相比于传统图像增强技术，深度学习图像增强技术能够更好地去除压缩伪影。然而，现有的深度学习增强模型存在计算复杂度过高、运算内存占用过大的问题，同时这些现有的网络只能解决单描述图像增强问题。将这些网络直接用于解决多描述增强任务时，只能单独地增强边路和中路解

码图像，无法联合边路和中路特征进行解码。为此，提出了一种联合边路和中路解码特征学习的多描述编码图像增强方法。首先，所提的方法需要使用多描述随机偏移量化(Multiple Description Random Offset Quantization，MDROQ)方法[25]对输入图像进行编码和解码。通过 MDROQ 方法可以获得两个带有失真的边路解码图像和一个中路解码图像。如图 1 所示，所提的方法将多描述图像增强分为低分辨率特征提取和高分辨率图像重建两个阶段。第一个阶段包括两个多描述边路低分辨率特征提取网络和一个多描述中路低分辨率特征提取网络。第二个阶段包括两个多描述边路上采样重建网络和一个多描述中路上采样重建网络。根据多描述编码的边路独立解码和中路联合解码的特性，设计了一种残差递归补偿网络结构并将其用于边路和中路的低分辨率特征提取网络。边路特征提取使用参数共享策略能够有效地提取两个外表相同但细节信息有所差异的两个描述解码图像的卷积特征。此外，所提的多描述边路上采样重建网络也采用部分网络层参数共享策略，这将极大地减小模型总参数量。

不同于边路上采样重建网络，多描述中路上采样重建网络将两个边路低分辨率特征与中路低分辨率特征进行深层特征融合来实现压缩图像的增强。所提方法的增强过程可以表示为

$$Y_i = X_i + R_i \, (i = 1,2,3) \tag{1}$$

其中，$i=1,2,3$ 分别表示边路 1、中路、边路 2，Y 表示增强后的图像，X 表示输入的图像，R 表示重建网络预测的残差图。

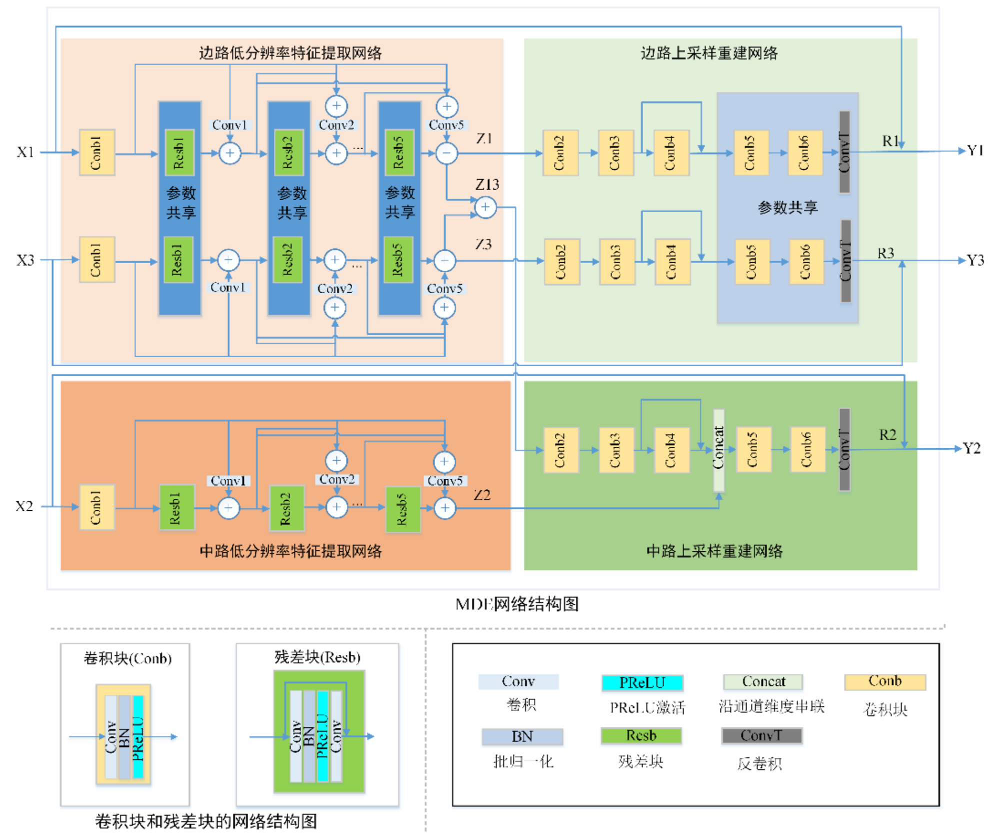


图 1 所提方法的网络结构

Fig. 1 Network structure in the proposed method

1.1 低分辨率特征提取网络

不同于单描述图像编码，考虑到多描述图像编码的输出包含多个边路解码图像和中路解码图像，所提的低分辨率特征提取网络包括两种：边路低分辨率特征提取网络和中路特征提取网络。为了避免在深度神经网络训练过程中模型出现过拟合的现象，同时降低深度神经网络的可学习参数量，所提的边路低分辨特征提取网络采用残差块参数共享策略来有效地提取低分辨率特征。与以往方法不同的是，这里的参数共享策略不是将两个边路网络都共享，而是进行部分块间的共享，同时在网络递归过程中，将递归结果使用 1*1 卷积进行处理，再将其与前一个递归块相加的结果输入下一个递归块，这样既有效地减少了网络参数量，又保证了不同支路间的差异性，该网络的结构如图 1 所示。中路低分辨率特征提取网络与边路低分辨率特征提取网络的相似点在于采用同一网络拓扑结构，但是这两个网络的可学习参数取值有所不同，如图 1 所示。

在两个边路和中路低分辨率特征提取网络中，首先使用一个卷积块的操作，即卷积(Convolution，Conv)+批归一化(Batch Normalization，BN)+PReLU(Parametric Rectified Linear Unit)激活函数，将其标记为 Conb。将图像转换为卷积特征，这里使用步长为 2 的下采样卷积操作来减少运算量，然后采用所提的残差递归补偿方式对该卷积特征进行多层融合。在这个补偿过程中，使用了五个残差卷积块(Residual Convolution Block，Resb)依次进行特征提取，同时将这些提取到的特征进行多次的通道加权平均融合。残差卷积块包括五个操作，即 Conv+BN+PReLU+Conv+跳跃连接。经过第五个残差卷积块的特征提取之后，将其与初始的卷积特征和前四次通道加权融合的特征再次进行通道加权特征融合得到该特征提取网络的低分辨率卷积特征。边中路低分辨率特征提取网络每层的参数如表 1 所示。具体来说，使用 Conb1 进行下采样同时提取图像的特征，将 Conb1 提取的图像特征输入到 Resb1 中，同时将 Conb1 提取的图像特征输入到 Conv1 中，将 Resb1 的输出与 Conv1 的输出的和作为 Resb2 的输入。在 Conv2 中，将 Resb1 的输入与 Resb2 的输入作为 Conv2 的输入，然后将 Resb2 的输出与 Conv2 的输出的和作为 Resb3 的输入。类似于 Resb2 和 Resb3 操作，Resb4 与 Resb5 执行同样的操作。在 Conv3 中，将 Resb1 的输入、Resb2 的输入、Resb3 的输入求和的结果作为 Conv3 的输入。类似于 Conv2 和 Conv3 操作，Conv4 与 Conv5 执行同样的残差递归补偿操作。最后，将 Resb5 的输出与 Conv5 的输出的和作为低分辨率特征提取网络的输出，同时，将两个边路低分辨率特征提

取网络输出的结果求和作为中路上采样重建网络的输入。概括来说，两个边路低分辨特征提取网络可以表示为

$$Z_i = g_s(X_i),(i=1,3) \tag{2}$$

$$Z_{13} = Z_1 + Z_3 \tag{3}$$

其中，Z_i 表示经过第 i 个边路低分辨率特征提取网络表示后的特征图，X_i 表示多描述解码的第 i 个边路图像，$g_s(\bullet)$ 表示边路 $X_i \to Z_i$ 的特征映射，即边路低分辨率特征提取网络的映射函数。Z_{13} 是 Z_1 和 Z_3 特征图像线性组合。类似地，中路低分辨率特征提取网络可以表示为

$$Z_2 = g_c(X_2) \tag{4}$$

其中，Z_2 表示经过中路低分辨率特征提取网络表示后的特征图，X_2 表示多描述中路解码图像，$g_c(\bullet)$ 表示中路 $X_2 \to Z_2$ 的特征映射，即中路低分辨率特征提取网络的映射函数。

表 1　边路和中路低分辨率特征提取网络的实现细节

Tab. 1　Implementation details of side and central low-resolution feature extraction network.

模块	卷积核大小	卷积步长	零填充的尺寸
Conb-1	3	2	1
Resb-1	3	1	1
Conv-1	1	1	0
Resb-2	3	1	1
Conv-2	1	1	0
Resb-3	3	1	1
Conv-3	1	1	0
Resb-4	3	1	1
Conv-4	1	1	0
Resb-5	3	1	1
Conv-5	1	1	0

1.2　边路和中路上采样重建网络

经过上述边路低分辨率特征提取网络和中路低分辨率特征提取网络后，分别可以得到两组边路低分辨率卷积特征图和一组中路低分辨率卷积特征图。在第一个边路上采样重建网络中，将得到的第一个边路低分辨率特征输入到五个串联的卷积块操作得到重建特征，同时在第三个卷积块操作中引入跳跃连接，有助于梯度反向传播。最后，将得到的重建特征输入到上采样(Transposed Convolution，ConvT)卷积层，即可得到第一个边路解码增强图像。类似地，第二个边路上采样重建网络也是如此。如图 1 所示，在两个边路上采样重建网络中，深层的卷积层采用参数共享策略，这种策略能够保证参数量较少的同时增强图像重建效果。

不同于边路上采样重建网络，中路上采样重建网络不仅可以使用从两个边路解码图像提取的特征图，而且还可以使用从中路解码图像提取的特征图。因此，在边路上采样重建网络的结构之上，设计了能够融合这些特征图的中路上采样重建网络。中路上采样重建网络与边路上采样重建网络都使用了五个卷积块操作，但不同的是在跳跃连接之后将得到的边路融合特征与中路低分辨率特征沿通道维度进行串联，同时在中路上采样重建网络中深层的卷积层没有与边路重建网络进行参数共享，这样做的主要原因是第四个卷积块的输入特征图之间存在较大差异，如图 1 所示。边路和中路重建网络每层的参数如表 2 所示。边路上采样重建网络的非线性映射关系可以表示为

$$R_1 = f_{s1}(Z_1) \tag{5}$$

$$R_3 = f_{s3}(Z_3) \tag{6}$$

其中，R_1 和 R_3 分别表示两个边路经低分辨率提取网络和特征上采样重建网络重建后的图像，Z_1 和 Z_2 表示经低分辨率特征提取后的图像，$f_{s1}(\cdot)$ 和 $f_{s3}(\cdot)$ 分别表示两个边路上采样重建网络的映射函数。中路上采样重建网络的非线性映射关系可以表示为

$$R_2 = f_c(Z_1, Z_2, Z_3) \tag{7}$$

其中，R_2 表示经低分辨率提取网络和特征上采样重建网络重建后的图像，Z 表示经低分辨率特征提取后的图像，$f_c(\bullet)$ 表示 $Z \to R$ 中路上采样重建网络的映射函数。最后，所提方法的边路和中路的整个非线性映射关系可以表示为

$$Y_1 = X_1 + R_1 = X_1 + f_{s1}(Z_1) = X_1 + f_{s1}(g_s(X_1)) \tag{8}$$

$$\begin{aligned} Y_2 &= X_2 + R_2 = X_2 + f_c(Z_1, Z_2, Z_3) \\ &= X_2 + f_c(g_s(X_1), g_c(X_2), g_s(X_3)) \end{aligned} \tag{9}$$

$$Y_3 = X_3 + R_3 = X_3 + f_{s3}(Z_3) = X_3 + f_{s3}(g_s(X_3)) \tag{10}$$

其中，Y_1、Y_2 和 Y_3 分别表示边路 1、中路、边路 2 增强后的图像，X_1、X_2 和 X_3 分别表示输入的边路 1、中路、边路 2 解码图像，R_1、R_2 和 R_3 分别表示经低分辨率提取网络和特征上采样重建网络重建后的边路 1、中路和边路 2 残差图，$f_{s1}(\bullet)$、$f_c(\bullet)$ 和 $f_{s3}(\bullet)$ 分别表示 $Z_1 \to R_1$、$(Z_1, Z_2, Z_3) \to R_2$ 和 $Z_3 \to R_3$ 的特征映射函数。

表 2　边路和中路上采样重建网络的实现细节

Tab. 2　The implementation details of side and central up-sampling reconstruction network

边路上采样重建网络				中路上采样重建网络			
模块	卷积核大小	卷积步长	零填充的尺寸	模块	卷积核大小	卷积步长	零填充的尺寸
Conb-2	3	1	1	Conb-2	3	1	1
Conb-3	3	1	1	Conb-3	3	1	1
Conb-4	3	1	1	Conb-4	3	1	1
Conb-5	3	1	1	Conb-5	3	1	1
Conb-6	3	1	1	Conb-6	3	1	1
ConvT	5	2	2	ConvT	5	2	2

1.3　损失函数

现有图像重建损失包括内容损失、结构不相似性损失、全变分损失和梯度差损失等。对于图像重建的内容损失，往往采用 L1 范数或 L2 范数来构建损失函数。很多的研究工作表明由 L2 范数构建的均方误差损失会使得经过该损失函数约束的模型输出结果呈现过度平滑的效果。与之相比，由 L1 范数构建的平均绝对误差损失函数会使得经过该损失函数约束的模型输出结果和原图更接近。因此，本文采用平均绝对误差损失来作为图像增强任务的损失函数。所提方法的总损失 Loss 可以表达为

$$Loss = \alpha Loss_1 + \beta Loss_2 + \alpha Loss_3 \tag{11}$$

$$Loss_1 = \frac{1}{n}\sum_{i=1}^{n}\left\| I_{1i} - \tilde{I}_{1i} \right\| \tag{12}$$

$$Loss_2 = \frac{1}{n}\sum_{i=1}^{n}\left\| I_{2i} - \tilde{I}_{2i} \right\| \tag{13}$$

$$Loss_3 = \frac{1}{n}\sum_{i=1}^{n}\left\| I_{3i} - \tilde{I}_{3i} \right\| \tag{14}$$

其中，$Loss_1$、$Loss_2$ 和 $Loss_3$ 分别为第一个边路解码图像增强损失和中路解码图像增强损失以及第二个边路解码图像增强损失。I_{1i} 和 $\tilde{I}_{1i}$ 分别为第一个边路的预测输出图和原始图像的第

i 个像素，n 为原始图像的像素总数，其他标记类似。α 为边路损失函数的权重，β 为中路损失函数的权重。

1.4 算法描述

本文所使用的训练数据集和测试数据集均来自于文献[26]。该数据集使用文献[27]和文献[28]的 291 张图像来获得训练图像块集合，其中 91 张图像来自于文献[27]的训练数据集，其余 200 张图像来自于文献[28]的 BSDS500 训练数据集。文献[26]使用裁切、下采样和图像拼接的方式来得到训练数据集，最终获得 1681 张大小为 160*160 的图像，将该数据集简称为 Set-1681。通过多描述随机偏移量化方法(MDROQ)对 Set-1681 数据集进行压缩来获得压缩后的数据集 Set-1681(C)，使用数据集 Set-1681 和 Set-1681(C)来构建 MDE 网络的训练数据集。这里，使用不同量化参数对(Qstep0,Qstep1)分别为(56,56.57)(96,96.57)(136,136.57)(176,176.57)和(216,216.57)来获得不同失真程度的压缩图像。当量化参数对(Qstep0,Qstep1)越小时，多描述图像压缩失真越小，即保留更多的原始信息。虽然训练数据集的大小和图像类型会影响深度学习网络的性能，但是本文所有对比方法的训练数据集和测试数据集都是相同的，从而保证了对比的公平性。

接下来，将介绍所提 MDE 网络的训练算法。如算法 1 所示，首先利用多描述随机偏移量化方法(MDROQ)压缩 Set-1681 数据集，然后，构建 MDE 网络训练所需的数据集。其次，对边路低分辨率特征提取网络参数 ζ 、中路低分辨率特征提取网络参数 η、边路上采样重建网络参数 λ 和中路上采样重建网络参数 ξ 进行初始化。接下来，根据式(2)进行边路低分辨率特征提取，与此同时，根据式(4)进行中路低分辨率特征提取。考虑到多描述边路解码的独立性和中路的联合解码，根据式(5)(6)和(7)进行边路和中路上采样重建预测。为了联合优化边路解码特征和中路解码特征，依据图像增强任务的总损失函数表达式(11)，通过梯度下降法更新网络参数 ζ、η、λ 和 ξ。经过训练后，输出并保存训练好的 MDE 网络模型。

算法 1 MDE 网络的训练算法

输入：Set-1681 数据集(图像总数 n=1681 张)，MDE 网络优化的总迭代次数 R=500，优化器的初始学习率 Lr=2e-4，更新 MDE 网络的图像批大小 b=8。

输出：训练好的 MDE 网络模型。

使用多描述随机偏移量化方法(MDROQ)压缩 Set-1681 数据集，得到压缩后的数据集，标记为 Set-1681(C)；使用 Set-1681 数据集和 Set-1681(C)构建 MDE 网络训练所需的数据集。

对 MDE 网络参数进行初始化设置(边路低分辨率特征提取网络参数为 ζ，中路低分辨率特征提取网络参数为 η，边路上采样重建网络参数为 λ，中路上采样重建网络参数为 ξ)。

for epoch =1 to R **do**

  for i=1 to floor(n/b) **do**

  根据式(2)进行边路低分辨率特征提取，同时根据式(4)进行中路低分辨率特征提取；考虑到多描述边路解码的独立性和中路的联合解码，根据式(5)~(7)进行边路和中路上采样重建预测。

  为了联合优化边路解码特征和中路解码特征，依据图像增强任务的总损失函数表达式(11)，通过梯度下降法更新 MDE 网络参数 ζ、η、λ 和 ξ。

  end for

end for

最后，输出并保存 MDE 网络模型。

2 实验结果与分析

为了验证所提 MDE 方法的有效性，将其与现有的多个深度学习方法如 ARCNN[5]、FastARCNN[5]、DnCNN[6]、WSR[14]、DWCNNV1[13]、DWCNNV1C[13]和 DWCNNV2[12]进行比较。本实验将方法 ARCNN、FastARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1C 和 DWCNNV2 的边路 1、边路 2 和中路增强网络分别使用同一网络架构，但网络参数有所不同。考虑到 WSR 是一种基于小波变换的图像超分辨率方法，将 WSR 网络的上采样层去除来实现多描述压缩图像的增强。图 2 所展示的图像来自于文献[26]，将这些图像用于测试所提方法、ARCNN、FastARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1C 和 DWCNNV2 方法的性能。这里，将不仅使用客观质量评价指标 PSNR 和 SSIM 来比较各种图像质量增方法的性能，而且使用网络的总参数量、网络感知野的大小以及运行时间来评估这些方法的性能。此外，还将展示这些方法增强后图像的视觉效果对比图。


(a)

(b)

(c)

(d)

图 2 测试数据集的样本示例图

Fig. 2 Sample diagram of testing dataset

2.1 仿真环境与训练设置

本文在深度学习框架 PyTorch 下使用 NVIDIA RTX 2080Ti GPU 显卡来训练和测试所提的方法。采用 ADAM 优化器来训练所提的 MDE 网络，该优化器的初始学习率 lr 设置为 2e-4，每迭代 100 次更新一次学习率，学习率的乘性衰减率为 0.5。每次使用批大小 b 为 8 的一组图像来更新网络参数，网络训练的总迭代次数为 R=500。

2.2 客观和主观质量评价

为了验证所提方法的可行性，本实验将其与多个最新图像增强方法，如 ARCNN[5]、FastARCNN[5]、DnCNN[6]、WSR[14]、DWCNNV1[13]、DWCNNV1C[13]和 DWCNNV2[12]进行了比较，结果如表 3~5 所示，其中最好的结果用双下划线加粗字体表示，排名第二的结果用单下划线加粗字体表示,排名第三的结果用加粗字体表示。如表 3~5 所示，当(Qstep0,Qstep1)=(56, 56.57)(96, 96.57)(136, 136.57)(176, 176.57)和(216, 216.57)时，给出了不同方法的客观评价指标 PSNR 和 SSIM 对比结果。通过对比可以发现，经过所提方法增强的两个边路及中路解码图像的客观评价指标 PSNR 和 SSIM 明显高于其他方法。

如表 6 所示，将所提的方法与 ARCNN、FastARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1C 和 DWCNNV2 方法的网络参数量进行对比。从该表可以发现 ARCNN、FastARCNN、WSR、DWCNNV1、DWCNNV1C 的参数量是本文方法参数量的一倍多，而且这些方法的 PSNR 和 SSIM 指标低于本文方法。虽然 DnCNN 和 WSR 方法与所提方法的参数总量非常接近，但是经过所提方法增强的图像的客观评价指标 PSNR 和 SSIM 高于这两个方法。

如图 3~5 所示，将经过所提的方法、ARCNN、FastARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1CD 和 WCNNV2 方法增强后的压缩图像进行比较。通过对比可以发现，边路解码图像存在严重的结构分裂伪影，而中路解码图像包含更多细节同时更加清晰。相比于 ARCNN、FastARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1C 和 DWCNNV2，所提方法能够使得增强后的压缩图像更清晰。如图 3 所示，从该视觉对比图中可以看出，经过 ARCNN、FastARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1C 和 DWCNNV2 增强的压缩图像仍然存在严重的模糊伪影。与这些方法相比，所提方法的中路图像视觉效果更好一些，这进一步验证了本文所提方法的有效性。从图 4、5 可以看出，经过 ARCNN、FastARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1C 和 DWCNNV2 方

法增强后的压缩图像视觉效果非常接近，而经过所提方法增强的多描述压缩图像视觉效果仍然更好。

表 3　在不同(Qstep0,Qstep1)下经过多描述图像编码方法 MDROQ 压缩的第一个边路增强图像的客观质量对比

Tab. 3　Objective quality comparison of the first side enhancement image under different (Qstep0,Qstep1) compressed by multi-description image coding method MDROQ

对比方法	(56,56.57)		(96,96.57)		(136,136.57)		(176,176.57)		(216,216.57)	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
MDROQ	31.54	0.8435	29.06	0.7822	27.58	0.7402	26.13	0.6995	25.33	0.6692
ARCNN	32.42	0.8588	30.03	0.8049	28.59	0.7659	27.31	0.7315	26.32	0.7026
FastARCNN	32.26	0.8566	30.01	0.8047	28.56	0.7662	27.28	0.7313	26.40	0.7045
WSR	32.31	0.8561	29.92	0.8013	28.42	0.7606	27.06	0.7246	26.14	0.6967
DnCNN	32.47	0.8595	30.09	0.8052	28.57	0.7642	27.21	0.7276	26.30	0.6988
DWCNNV2	32.31	0.8577	29.89	0.8024	28.47	0.7668	27.20	0.7310	26.04	0.7000
DWCNNV1	32.50	0.8624	30.08	0.8084	28.45	0.7665	27.22	0.7319	26.17	0.7039
DWCNNV1C	32.35	0.8593	30.08	0.8078	28.49	0.7664	27.26	0.7332	26.25	0.7061
本文方法	32.52	0.8613	30.22	0.8100	28.59	0.7674	27.38	0.7342	26.48	0.7081

表 4　在不同(Qstep0,Qstep1)下经过多描述图像编码方法 MDROQ 压缩的第二个边路增强图像的客观质量对比

Tab. 4　Objective quality comparison of the second side enhancement image under different (Qstep0,Qstep1) compressed by multi-description image coding method MDROQ

对比方法	(56,56.57)		(96,96.57)		(136,136.57)		(176,176.57)		(216,216.57)	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
MDROQ	31.54	0.8431	29.04	0.7828	27.60	0.7407	26.15	0.6981	25.38	0.6689
ARCNN	32.40	0.8589	30.03	0.8053	28.57	0.7659	27.27	0.7329	26.30	0.7025
FastARCNN	32.25	0.8563	30.01	0.8046	28.55	0.7652	27.26	0.7324	26.37	0.7046
WSR	32.28	0.8561	29.92	0.8011	28.41	0.7605	27.04	0.7254	26.11	0.6962
DnCNN	32.46	0.8597	30.14	0.8066	28.60	0.7638	27.18	0.7281	26.26	0.6986
DWCNNV2	32.33	0.8579	29.13	0.7879	28.37	0.7647	27.21	0.7316	26.15	0.7044
DWCNNV1	32.49	0.8624	30.11	0.8080	28.48	0.7669	27.18	0.7322	26.12	0.7017
DWCNNV1C	32.32	0.8592	30.06	0.8074	28.53	0.7684	27.22	0.7339	26.16	0.7046
本文方法	32.55	0.8628	30.25	0.8099	28.65	0.7690	27.41	0.7364	26.47	0.7085

表 5　在不同(Qstep0,Qstep1)下经过多描述图像编码方法 MDROQ 压缩的中路增强图像的客观质量对比

Tab. 5　Objective quality comparison of the central path enhancement image under different (Qstep0,Qstep1) compressed by multi-description image coding method MDROQ

对比方法	(56,56.57)		(96,96.57)		(136,136.57)		(176,176.57)		(216,216.57)	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
MDROQ	32.35	0.8591	29.85	0.8019	28.41	0.7619	26.94	0.7230	26.16	0.6944
ARCNN	33.09	0.8704	30.69	0.8159	29.25	0.7814	27.95	0.7480	26.94	0.7198
FastARCNN	32.94	0.8681	30.63	0.8181	29.19	0.7805	27.90	0.7475	27.01	0.7207
WSR	33.02	0.8684	30.60	0.8162	29.14	0.7776	27.71	0.7433	26.76	0.7154
DnCNN	33.15	0.8710	30.78	0.8193	29.26	0.7802	27.86	0.7445	26.96	0.7164
DWCNNV2	33.09	0.8706	30.67	0.8182	29.04	0.7766	27.98	0.7511	26.68	0.7190
DWCNNV1	33.21	0.8733	30.84	0.8226	29.23	0.7828	27.95	0.7508	26.92	0.7229
DWCNNV1C	32.87	0.8678	30.77	0.8217	29.15	0.7831	28.04	0.7512	26.91	0.7223
本文方法	33.25	0.8737	30.94	0.8238	29.35	0.7851	28.12	0.7535	27.13	0.7259

表 6 不同方法的参数量大小比较(1M=10e+6)

Tab. 6　Comparison of parameter numbers for different methods (1M=10e+6)

对比方法	网络总参数量
ARCNN	0.64M
FastARCNN	0.66M
WSR	0.62
DnCNN	0.34M
DWCNNV2	4.69M
DWCNNV1	8.61M
DWCNNV1C	0.71M
本文方法	0.32M

2.3　复杂度分析

如表 7 所示，将所提方法与 ARCNN、FastARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1C 和 DWCNNV2 方法的感知野进行对比。从该表中可以发现：所提方法的感知野比 ARCNN、FastARCNN、DnCNN、DWCNNV1 和 DWCNNV1C 方法更大。但是，所提方法的感知野比 WSR 和 DWCNNV2 方法小。

表 7　不同方法的感知野大小比较

Tab. 7　Comparison of receptive field size for different methods

对比方法	感知野	对比方法	感知野
ARCNN	55	DWCNNV2	217
FastARCNN	141	DWCNNV1	145
WSR	967	DWCNNV1C	145
DnCNN	31	本文方法	187

如表 8 所示，将所提方法不同感知野在量化参数对(Qstep0, Qstep1)为(216, 216.57)时中路图像的 PSNR 和 SSIM 进行对比。

从该表中可以发现，随着感知野的增加，所提方法的性能将有所提高。但是当感知野的值大于 103 时，性能将逐渐趋于饱和状态。此外，从该表中还可以发现，当不同感知野的增强模型拥有相同级别的参数时，它们的运行时间基本上差别不大。一般来说，大感知野的神经网络可以利用更多的空间相关性。虽然网络的性能在一定程度上受到感知野的影响，但是随着感知野的不断增加，空间位置差别较大的两个像素之间的相关性也会变弱，同时也增加神经网络的复杂度。由此可见，神经网络的感知野并不是越大越好。为了验证所提方法的有效性，将所提方法与 ARCNN、FastARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1C 和 DWCNNV2 方法的运行时间进行比较，如表 9 所示。由表 9 可知：所提方法的运行时间比 FastARCNN 慢 0.007 秒，但它比 ARCNN、DnCNN、WSR、DWCNNV1、DWCNNV1C 和 DWCNNV2 方法都快。

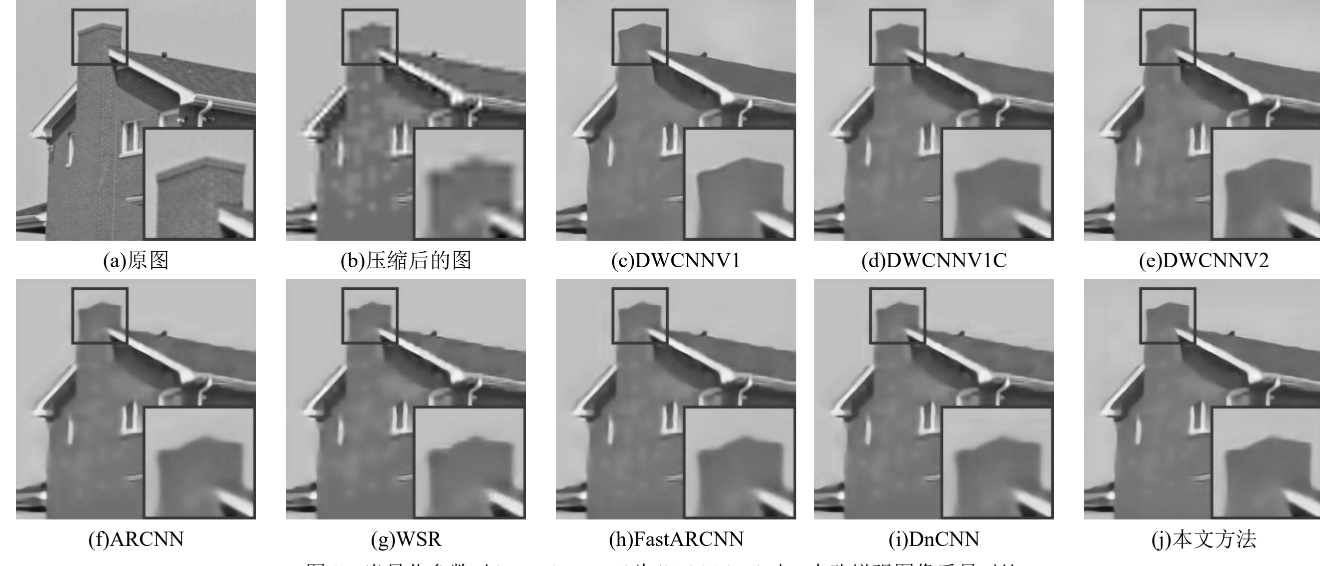


图 3 当量化参数对(Qstep0,Qstep1)为(216,216.57)时，中路增强图像质量对比

Fig. 3 Image quality comparison of the central enhanced image with quantization parameter pair (Qstep0,Qstep1)= (216,216.57)

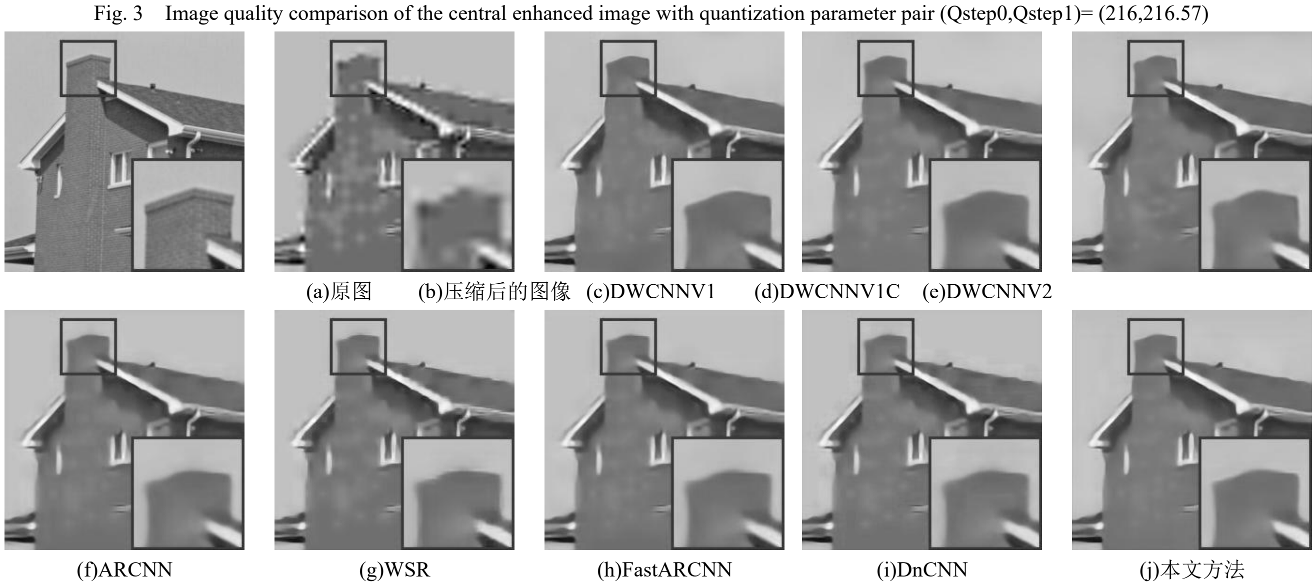


图 4 当量化参数对(Qstep0,Qstep1)为(216,216.57)时，第一个边路增强图像质量对比

Fig. 4 Image quality comparison of the first side enhanced image with quantization parameter pair (Qstep0,Qstep1)= (216,216.57)

表 8 在量化参数对(Qstep0,Qstep1)为(216,216.57)时，所提方法使用不同感知野的图像客观质量、网络总参数量和运行时间比较

Tab. 8 When the quantization parameter pair (Qstep0,Qstep1) is (216,216.57), the proposed method compares the objective image quality, the number of total network parameters and the running time of different receptive fields

感知野	PSNR/SSIM	感知野	PSNR/SSIM
43	27.06/0.7219	187	27.13/0.7259
67	27.07/0.7233	223	27.10/0.7248
103	27.14/0.7246	367	27.11/0.7261
127	27.14/0.7250		

考虑到 ARCNN 网络提取的特征存在着大量的冗余信息，而且该网络需要通过增加网络参数量来提升该网络的性能，这势必增加运行时间、计算成本和存储空间。虽然 FastARCNN 一定程度缓解了这些问题，但在量化参数对(Qstep0,Qstep1)较小即图像质量较高时，该方法恢复效果较差。相比于浅层网络 ARCNN 和 FastARCNN 方法，使用更深网络结构的 DnCNN 方法能够提升增强后的图像质量，但是也会增加网络的计算量。WSR 和 DWCNNV 方法主要使用小波分解技术来解决图像增强问题。上述方法能够解决多描述压缩图像增强问题，但是它们并没有考虑到多描述编码的边路独立解码和中路联合解码的特性，而所提方法的网络结构可以充分利用多描述编码的边路独立解码和中路联合解码的特性以及参数共享的策略，在降低网络复杂度的同时扩大感知野使图像拥有更多的空间相关性。由此可见，本文方法是一种非常有效的多描述压缩图像增强方法。

2.4 消融实验与分析

为了更好地分析所提的方法，将从以下四个方面进行消融实验仿真，即残差卷积块个数、边中路损失权重、训练批大小和学习率。首先，本实验提供了残差卷积块个数的消融

实验结果，如表 10 所示。在量化参数对(Qstep0, Qstep1)为(56, 56.57)时，该表给出了当残差卷积块分别为 1、3、5、7 和 9 时所提方法的性能变化情况。从该表中可以看出，当残差卷积块的个数大于 5 时，所提方法的性能趋于稳定，但其参数量必然增加。在默认情况下，将残差卷积块的数量设置为 5。其次，多描述编码图像不仅存在压缩伪影问题，而且存在不同程度的结构分裂问题，在训练时边路和中路的损失权重会影响所提方法的性能。本实验提供了当边路和中路损失函数边中路权重比分别是 0.1:1、0:0.1 和 1:1 时所提方法的性能对比，如表 11 所示。经过对比可知，当边中路损失函数权重为 1:1 时，所提方法的 PSNR 和 SSIM 指标最高。一般来说，CNN 网络训练的超参数会影响网络的性能。最后，本实验提供了所提方法的学习率和批大小消融实验结果。如表 12 所示，对批大小为 4、8、12 和 16 进行了实验仿真。从该表中可以看出，所提方法对批大小不敏感。当批大小为 8 时，所提方法的 PSNR 和 SSIM 指标最高。如表 13 所示，本消融实验对学习率为 1e-4、2e-4 和 3e-4 分别进行实验仿真。从该表中可以发现所提方法对学习率也不敏感。虽然使用学习率为 3e-4 训练的模型的 PSNR 比 2e-4 的略高，但是使用学习率为 3e-4 训练的模型的 SSIM 比 2e-4 低，考虑到人眼更关注于图像的结构区域，在默认情况下将学习率设定为 2e-4。

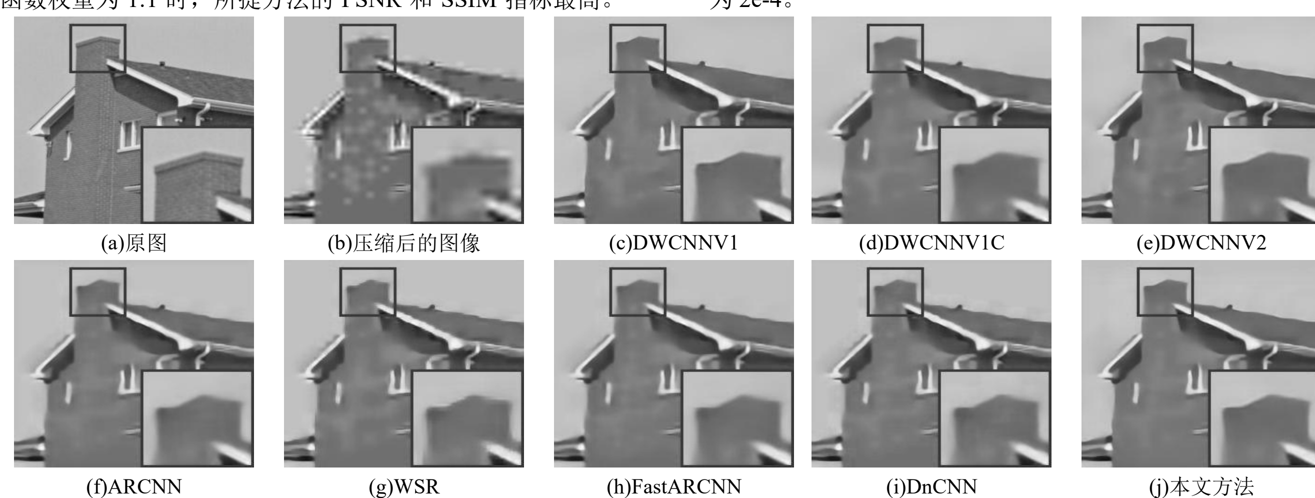

(a)原图　(b)压缩后的图像　(c)DWCNNV1　(d)DWCNNV1C　(e)DWCNNV2
(f)ARCNN　(g)WSR　(h)FastARCNN　(i)DnCNN　(j)本文方法

图 5　当量化参数对(Qstep0,Qstep1)为(216,216.57)时，第二个边路增强图像质量对比

Fig. 5　Image quality comparison of the second side enhanced image with quantization parameter pair (Qstep0,Qstep1)= (216,216.57)

表 9　不同方法的平均运行时间比较

Tab. 9　Comparison of average running time of different methods

对比方法	运行时间(秒/张)	对比方法	运行时间(秒/张)
ARCNN	0.045	DWCNNV2	0.056
FastARCNN	0.013	DWCNNV1	0.094
WSR	0.085	DWCNNV1C	0.032
DnCNN	0.022	本文方法	0.02

3　结束语

针对多描述编码的压缩失真问题，本文提出一种联合边路和中路解码特征学习的多描述编码图像增强方法。首先，提出一种残差递归网络，并将其作为边路和中路的低分辨率特征提取网络。其次，根据边路和中路的解码特性采用参数共享策略来有效地提取两个内容相同且具有差异性的边路图像特征。最后，将两个边路低分辨率特征/中路低分辨率特征通过边路/中路上采样重建网络来实现多描述压缩图像的增强。大量的实验结果表明，在模型复杂度、客观质量评价和视觉质量方面，本文方法优于很多的深度学习图像增强方法。在未来的工作中，将考虑使用单个深度学习模型解决不同量化参数下多描述编码图像的增强问题。

表 10　所提方法的残差卷积块个数消融实验结果对比

Tab. 10　Ablation study on the proposed method with different numbers of residual convolution blocks

类别	残差卷积块个数				
	1	3	5	7	9
边路 1	32.33/0.8583	32.47/0.8610	32.52/0.8613	32.53/0.8613	32.53/0.8608
边路 2	32.43/0.8587	32.54/0.8621	32.55/0.8628	32.57/0.8613	32.58/0.8629
中路	33.13/0.8703	33.24/0.8731	33.25/0.8737	33.27/0.8743	33.27/0.8738
平均数	32.63/0.8624	32.75/0.8654	32.77/0.8659	32.79/0.8656	32.79/0.8658

表 11　所提方法的不同边中路损失权重消融实验结果对比

Tab. 11　Ablation study on the proposed method with different side and central path loss weights

权重	边路 1	边路 2	中路	平均数
α：β=0.1:1	32.44/0.8579	32.55/0.8624	33.25/0.8734	32.75/0.8646
α：β=1:0.1	32.31/8.8534	32.52/0.8625	33.23/0.8737	32.69/0.8632
α：β=1:1	32.52/0.8613	32.55/0.8628	33.25/0.8737	32.77/0.8659

表 12 所提方法的不同批大小消融实验结果对比

Tab. 12　Ablation study on proposed method with different batch-size

批大小	边路 1	边路 2	中路	平均数
4	32.49/0.8623	32.52/0.86270	33.23/0.8740	32.75/0.8663
8	32.52/0.8613	32.55/0.8628	33.25/0.8737	32.77/0.8659
12	32.38/0.8595	33.55/0.8620	33.24/0.8737	32.72/0.8649
16	32.51/0.8630	32.52/0.8616	33.22/0.8729	32.75/0.8658

表 13 所提方法的不同学习率消融实验结果对比

Tab. 13　Ablation study on proposed method with different learning rates

学习率	边路 1	边路 2	中路	平均数
1e-4	32.47/0.8604	32.50/0.8617	33.18/0.8724	32.72/0.8648
2e-4	32.52/0.8613	32.55/0.8628	33.25/0.8737	32.77/0.8659
3e-4	32.52/0.8597	32.58/0.8626	33.28/0.8739	32.79/0.8654

参考文献：

[1] Dabov K, Foi A, Katkovnik V, *et al.* Image denoising by sparse 3D transform domain collaborative filtering [J]. IEEE Trans on Image Processing, 2007, 16 (8): 2080–2095.

[2] Foi A, Katkovnik V, Egiazarian K. Pointwise shape-adaptive dct for high-quality denoising and deblocking of grayscale and color images [J]. IEEE Trans on Image Processing, 2007, 16 (5): 1395–1411.

[3] Chang Huibin, Michael K Ng, Zeng Tieyong. Reducing artifacts in jpeg decompression via a learned dictionary [J]. IEEE Trans on Signal Processing, 2014, 62 (3): 718–728.

[4] Zhang Jian, Xiong Ruiqin, Zhao Chen, *et al.* CONCOLOR: Constrained non-convex low-rank model for image deblocking [J]. IEEE Trans on Image Processing, 2016, 25 (3): 1246-1259.

[5] Dong Chao, Deng Yubin, Chen Chang Loy, *et al.* Compression artifacts reduction by a deep convolutional network [C]// Proceedings of the IEEE International Conference on Computer Vision. 2015: 576-584.

[6] Zhang Kai, Zuo Wangmeng, Chen Ynjin, *et al.* Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising [J]. IEEE Trans on Image Processing, 2017, 26 (7): 3142–3155.

[7] Qiu Han, Zheng Qinkai, Memmi Gerard, *et al.* Deep residual learning based enhanced JPEG compression in the internet of things [J]. IEEE Trans on Industrial Informatics, 2020, 17: 2124-2133.

[8] 陈书贞，张祎俊，练秋生．基于多尺度稠密残差网络的 JPEG 压缩伪迹去除方法 [J]. 电子与信息学报, 2019, 41 (10): 2479-2486. (Chen Shuzhen, Zhang Yijun, Lian Qiusheng. JPEG compression artifacts reduction algorithm based on multi-scale dense residual network [J]. Journal of Electronics and Information Technology, 2019, 41 (10): 2479-2486.)

[9] Zhang Xiaoshuai, Yang Wenhan, Hu Yueyu, *et al.* DMCNN: dual-domain multi-scale convolutional neural network for compression artifacts removal [C]// The 25th IEEE International Conference on Image Processing (ICIP) . IEEE, 2018: 390-394.

[10] Zhang Bolun, Chen Yaowu, Tian Xiang, *et al.* Implicit dual-domain convolutional network for robust color image compression artifact reduction [J]. IEEE Trans on Circuits and Systems for Video Technology, 2020, 30: 3982-3994.

[11] Jin Zhi, Muhammad Zafar Iqbal, Bobkov Dmytro, *et al.* A flexible deep CNN framework for image restoration [J]. IEEE Trans on Multimedia, 2019, 22 (4): 1055-1068.

[12] Liu Pengju, Zhang Hongzhi, Lian Wei, *et al.* Multi-level wavelet convolutional neural networks [J]. IEEE Access, 2019, 7: 74973-74985.

[13] Liu Pengju, Zhang Hongzhi, Zhang Kai, *et al.* Multi-level wavelet-CNN for image restoration [C]// Proceedings of the IEEE conference on computer vision and pattern recognition workshops. 2018: 773-782.

[14] Zhang Huanrong, Jin Zhi, Tan Xiaojun, *et al.* Towards lighter and faster: Learning wavelets progressively for image super-resolution [C]// Proceedings of the 28th ACM International Conference on Multimedia. 2020: 2113-2121.

[15] Li Jianwei, Wang Yongtao, Xie Haihua, *et al.* Learning a single model with a wide range of quality factors for JPEG image artifacts removal [J]. IEEE Trans on Image Processing, 2020, 29: 8842–8854.

[16] Kirmemis O, Bakar G, Tekalp A M. Learned compression artifact removal by deep residual networks [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. 2018: 2602-2605.

[17] 周航，何小海，王正勇，等．采用双网络结构的压缩视频超分辨率重建 [J]. 电讯技术, 2020, 60 (01): 81-86. (Zhou Hang, He Xiaohai, Wang Zhengyong, *et al.* Super-resolution reconstruction of compressed video with dual network structure. Telecommunication Technology [J] , 2020, 60 (01): 81-86.)

[18] 铉欣．基于多描述标量量化的分布式视频编码 [D]. 西安：西安电子科技大学, 2012.

[19] Zhao Lijun, Bai Huihui, Wang Anhong, *et al.* Multiple description convolutional neural networks for image compression [J]. IEEE Tran on Circuits and Systems for Video Technology, 2018, 29 (8): 2494-2508.

[20] Zhang Xiangjun, Wu Xiaolin. Standard-compliant multiple description image coding by spatial multiplexing and constrained least-squares restoration [C]// IEEE the 10th Workshop on Multimedia Signal Processing. IEEE, 2008: 349-354.

[21] Purica A, Boyadjis B, Pesquet P B, *et al.* A convex optimization framework for video quality and resolution enhancement from multiple descriptions [J]. IEEE Trans on Image Processing, 2018, 28 (4): 1661-1674.

[22] Zhang Ting, Bai Huihui, Zhang Mengmeng, *et al.* Standard-compliant multiple description image coding based on convolutional neural networks [J]. IEICE Trans on Information and Systems, 2018, 101 (10): 2543-2546.

[23] Zhu Shuyuan, He Zhiying, Meng Xiandong, *et al.* A new polyphase down-sampling-based multiple description image coding [J]. IEEE Trans on Image Processing, 29 (2020): 5596-5611.

[24] Xu Yuanyuan. Predictive side decoding for human-centered multiple description image coding [J]. EURASIP Journal on Wireless Communications and Networking, 2020 (2020): 1-14.

[25] Meng Lili, Liang Jie, Samarawickrama U, *et al.* Multiple description coding with randomly and uniformly offset quantizers [J]. IEEE Trans on Image Processing, 2013, 23 (2): 582-595.

[26] Zhao Lijun, Bai Huihui, WangAnhong, *et al.* Learning a virtual codec based on deep convolutional neural network to compress image. Journal of Visual Communication and Image Representation, 2019, 63: 102589-102599.

[27] Yang Jianchao, John W, Thomas S H, *et al.* Image super-resolution via sparse representation, IEEE Trans on Image Processing, 2010, 19 (11): 2861-2873.

[28] Pablo A, Michael M, Charless F, *et al.* Contour detection and hierarchical image segmentation [J]. IEEE Trans on pattern analysis and machine intelligence, 2010, 33 (5): 898-916.